



# POSGRADOS

MAESTRÍA EN \_\_\_\_\_

## ELECTRÓNICA Y AUTOMATIZACIÓN

RPC-SO-19-No.277-2018

OPCIÓN DE  
TITULACIÓN:

ARTÍCULOS PROFESIONALES DE ALTO NIVEL

TEMA:

DESARROLLO DE BIO CONTROLADORES META  
HEURÍSTICOS CON REALIMENTACIÓN POR  
VISIÓN ARTIFICIAL PARA UN SISTEMA  
ROLLINGBALL AND PLATE

AUTOR:

JAIRO ANDRES ALVEAR GUEVARA

DIRECTOR:

HAMILTON LEONARDO NUÑEZ VERDEZOTO

QUITO - ECUADOR  
2021

***Autor/a:***



***Jairo Andres Alvear Guevara***

Ingeniero en Mecatrónica

Candidato a Magíster en Electrónica y Automatización mención Informática Industrial por la Universidad Politécnica Salesiana – Sede Quito.

jairoalvear7@gmail.com

***Dirigido por:***



***Hamilton Leonardo Nuñez Verdezoto***

Ingeniero en Electrónica y Control

Magister en diseño, producción y automatización industrial

hnunez@ups.edu.ec

Todos los derechos reservados.

Queda prohibida, salvo excepción prevista en la Ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos investigativos por cualquier medio, con la debida notificación a los autores.

**DERECHOS RESERVADOS**

©2021 Universidad Politécnica Salesiana.

QUITO – ECUADOR – SUDAMÉRICA

ALVEAR GUEVARA JAIRO A.

***DESARROLLO DE BIO CONTROLADORES META HEURÍSTICOS CON REALIMENTACIÓN POR VISIÓN ARTIFICIAL PARA UN SISTEMA ROLLINGBALL AND PLATE***

# DESARROLLO DE BIO CONTROLADORES META HEURÍSTICOS CON REALIMENTACIÓN POR VISIÓN ARTIFICIAL PARA UN SISTEMA ROLLINGBALL AND PLATE

Hamilton Nuñez V., Jairo Alvear G.

Universidad Politécnica Salesiana - Ecuador

---

## Resumen

El Sistema Rolling/Ball and Plate tiene dos problemas para calibrar el PID que controlará al sistema. El primer problema es que el sistema no es lineal y el segundo es que existe un alto grado de incertidumbre al desarrollar el modelo matemático para aplicar los métodos de sintonización de controladores PID como Ziegler Nichols, lugar de las raíces, entre otras, esperando obtener un resultado óptimo. En este estudio, se desarrollaron seis bio-algoritmos relevantes para calibrar los controladores Proporcionales, Integrales y Derivados (PID) que siempre buscan los valores óptimos de las constantes del controlador PID. Una vez obtenidos los resultados, se aplicó una prueba estadística, finalmente se probó la sintonización de controladores PID por algoritmos meta heurísticos en la planta 33-240 del fabricante National Instruments con distintas señales de entrada y se analizó su comportamiento con el fin de comparar y obtener conclusiones sobre el desempeño de cada bioalgoritmo.

---

## Abstract

The Rolling/Ball and Plate system has two problems when calibrating the PID controller that will govern the system. The first problem is that the system is non-linear and the second one is that there is a high grade of uncertainty when developing the mathematical model so it is possible to apply the conventional tailor-made solutions like Ziegler Nichols, Root-Locus, and others and expect to have an optimal result. In this study, six relevant bio-algorithms were developed in order to calibrate the Proportional, Integral and Derivative (PID) controllers that always search for the optimal PID controller constant values. Once the results were obtained, a statistical test was applied, finally the tuning of PID controllers by meta-heuristic algorithms was tested in the plant 33-240 of the manufacturer National Instruments with different input signals and their behavior was analyzed in order to compare and obtain conclusions about the performance of each bioalgorithm.

---

**Palabras clave**— Controlador PID; Ball and Plate; Metaheurística; Programación Evolutiva; Algoritmo Genético; Algoritmo de forraje de bacterias; Algoritmo Evolutivo; Sistema Inmune Artificial; Optimización mediante Cúmulos de Partículas; Optimización por Colonia de Hormigas .

# 1 Introducción

El sistema ball and plate ha sido utilizado a lo largo de los años para el desarrollo de nuevos controladores por ser un sistema característico de control interesante y con gran complejidad de su dinámica, por tanto la academia ha presentado algunos trabajos que involucran técnicas modernas como lo exponen M. Moarref (Moarref et al., 2008), D. Colon (Colón et al., 2014) y M. Borah con L. Majhi (Borah et al., 2014).

Sin embargo, todavía se están buscando nuevas alternativas más eficaces que involucren el uso de la inteligencia computacional como lo muestran los trabajos de X. Dong con Z. Zhang (Zhang et al., 1999) y K. Han con Y. Tian (Kyongwon et al., 2012). Ambas aplicaciones muestran claramente capacidad de adaptación, alta robustez y buen rendimiento para cumplir con los requisitos de control solicitados.

Los controladores PID convencionales con los cuales se han venido trabajando los procesos, pueden ser repotenciados para que funcionen adecuadamente ante la demanda de la producción actual, resolviendo problemas como el offset de su valor proporcional, el windup de su valor integral, la sintonización de sus parámetros, etc., como lo expone X. Wang con M. Wu (Wang et al., 2010) optimizando los parámetros PID de un convertidor DC-DC usando algoritmos evolutivos o A. Lukman con M. Nuraddeen (Yusuf and Magaji, 2014) que sintonizan el control PID de posición de ángulo de un péndulo invertido con un algoritmo genético (GA-PID) y A. Bensenouci (Bensenouci, 2011) que desarrolló un controlador PID basado en el algoritmo de forraje de bacterias.

Usar la inteligencia artificial para sintonizar los parámetros de un controlador PID es una buena opción debido a que encontrar la combinación óptima de las tres constantes del controlador PID resultará en un balance conveniente entre el consumo de energía del actuador y la salida del sistema deseada.

Por lo mencionado anteriormente, este trabajo propone un análisis comparativo de seis algoritmos inspirados en diversos fenómenos de la naturaleza que buscan los valores óptimos de las constantes del controlador PID que se enumeran a continuación:

- Algoritmo Genético - GA
- Optimización Por Forraje De Bacterias - BFOA
- Programación Evolutiva - EP
- Sistema Inmune Artificial - SIA
- Optimización Por Cúmulo De Partículas - PSO
- Optimización Por Colonia De Hormigas - ACO

Es necesario determinar los rangos de las constantes PID para generar valores iniciales para definir la solución heurística inicial como la población, para el algoritmo genético. Para cada algoritmo bioinspirado, los detalles de implementación, los parámetros de entrada, las simulaciones relevantes y pruebas en la planta se mencionan y muestran para probar que, si bien la implementación es muy diferente, los resultados de la optimización convergen a valores óptimos globales.

## 2 Métodos

### 2.1 Función de transferencia

La función de transferencia detallada en (1), obtenida a partir de la información disponible por parte del fabricante NI complementada con experimentos en la planta 33-240, relaciona el ángulo de rotación del plato en radianes y el voltaje de alimentación de los inductores.

$$G(s) = \frac{0,1073 * s^2}{0,0008547 * s^4 - 0,01193} \quad (1)$$

### 2.2 Rango de búsqueda de constantes PID

La Figura 1 uno presenta el diagrama del controlador PID, en donde: r: Punto de consiga, e: Error, u: Señal de control y K: Ganancia. Sin embargo, para el Sistema BALL AND PLATE es suficiente un controlador PD.




Figura 1: Diagrama de control PID

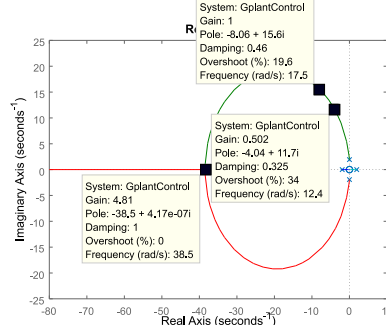


Figura 2: Lugar de las raíces

El controlador PD en paralelo utilizado tiene la forma de (2).

$$PD = kd * s^2 + kp \quad (2)$$

El tiempo de asentamiento requerido es  $T_s \leq 0,5s$  y el sobreimpulso permitido es  $OS = 20\%$ .

$$\zeta = \frac{-\ln\left(\frac{OS}{100}\right)}{\sqrt{\pi^2 + \left(\ln\left(\frac{OS}{100}\right)\right)^2}} = \frac{-\ln\left(\frac{20}{100}\right)}{\sqrt{\pi^2 + \left(\ln\left(\frac{20}{100}\right)\right)^2}} = 0,4559 \quad (3)$$

$$\omega_n = \frac{4}{T_s * \zeta} = \frac{4}{0,5 * 0,4559} = 17,5458 \frac{rad}{s} \quad (4)$$

La ubicación del polo en lazo cerrado se define a partir de (5).

$$s = -\zeta * \omega_n \pm j * \omega_n * \sqrt{1 - \zeta^2} = -8 \pm j15,6159 \quad (5)$$

$$s = -8 \pm j15,6159 \quad (6)$$

Utilizando la condición de ángulo del método del lugar de las raíces la deficiencia de ángulo es  $-54,26^\circ$ , por lo tanto el cero del controlador PD tiene que estar ubicado en  $s = -19,2376$ . De (7) se calcula  $k_c$ , la ganancia interna del controlador, utilizando la condición de magnitud del método del lugar de las raíces.

$$\left| k_c * (s + 19,2376) * \frac{0,1073 * s^2}{0,0008547 * s^4 - 0,01193} \right| = 1 \quad (7)$$

A partir de (7),  $k_c$  es igual a 0.1275.

La Figura 2 indica el lugar de las raíces que muestra que la localización del polo se completó con éxito, y también muestra los límites de ganancia permitidas del controlador.

- $0 \leq K$  : El sistema es estable
- $0,5 < K \leq 4,81$ : El sobreimpulso varía desde un 34% hasta 0%.
- $K = 1$  El sobreimpulso es inferior a 20%.

Tabla 1: Rangos de búsqueda iniciales

Constantes PD	Límite inferior	Límite superior
kp	1.22639	11.7979
kd	0.06375	0.61328

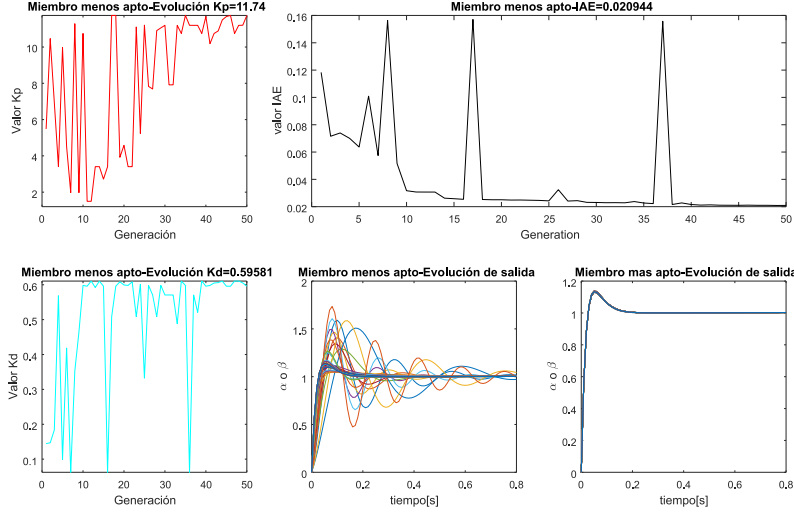


Figura 3: Proceso de optimización del Algoritmo Genético de un experimentos

En (9) y (11) se especifica la función de transferencia del controlador con los límites de ganancia definidos con  $K=0.5$  y  $K=4.81$ , respectivamente.

$$G_{PD-min}(s) = 0,5 * 0,1275 * (s^2 + 19,2376) \quad (8)$$

$$G_{PD-min}(s) = 0,06375 * s^2 + 1,22639 \quad (9)$$

$$G_{PD-max}(s) = 4,81 * 0,1275 * (s^2 + 19,2376) \quad (10)$$

$$G_{PD-max}(s) = 0,61328 * s^2 + 11,7979 \quad (11)$$

Comparando (2) con (9) y (11), los límites de búsqueda iniciales del controlador se detallan en la Tabla 1. Una vez definida el rango de búsqueda inicial se procede a aplicar la optimización a través de cada algoritmo.

### 2.3 Algoritmo Genético – GA

El algoritmo genético detallado en (Brownlee, 2011) fue aplicado con los parámetros detallado continuación:

- $Tamaño_{población} = 20$ , para evitar altos tiempos de ejecución.
- $Número_{generaciones} = 50$ , para evitar altos tiempos de ejecución.
- $Probabilidad_{cruce} = 99\%$ , como sugiere en (Brownlee, 2011).
- $Probabilidad_{mutación} = 33,33\%$ , como sugiere en (Brownlee, 2011).

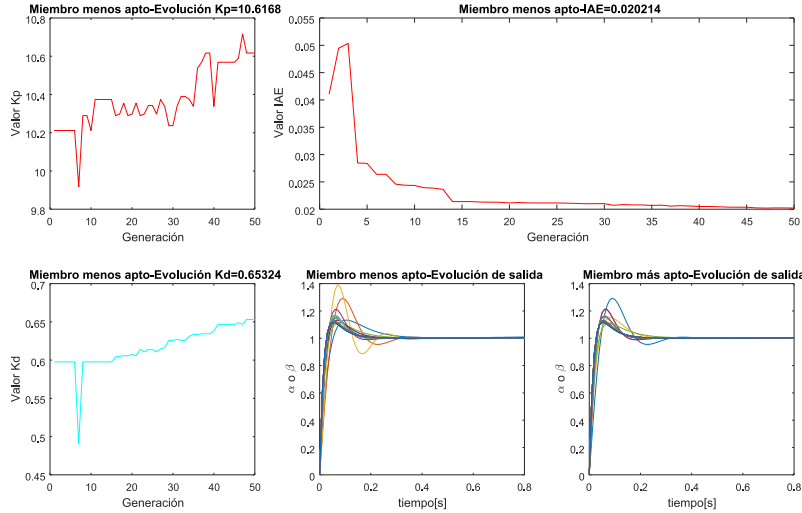


Figura 4: Proceso de optimización del Algoritmo de Programación Evolutiva de un experimento

La Figura 3 detalla la evolución de  $K_p$ ,  $K_d$ , salida e IAE del miembro menos apto de la población, así como la salida del miembro del miembro más apto. El IAE tiende a disminuir en cada generación como evidencia del proceso de optimización.

## 2.4 Programación evolutiva – EP

El algoritmo de programación evolutiva de (Brownlee, 2011) fue aplicado con los parámetros detallado continuación:

- $Tamaño_{población} = 20$ , para evitar altos tiempos de ejecución.
- $Número_{generaciones} = 50$ , para evitar altos tiempos de ejecución.
- $Tamaño_{contienda} = 2$ , (Brownlee, 2011) sugiere que el tamaño de contienda debe ser desde el 5% hasta el 10% del tamaño de la población.

La Figura 4 detalla la evolución de  $K_p$ ,  $K_d$ , salida e IAE del miembro menos apto de la población, así como la salida del miembro del miembro más apto. El IAE tiende a disminuir en cada generación como evidencia del proceso de optimización.

Comparando el proceso de evolución entre el Algoritmo Genético y la Programación Evolutiva para las ejecuciones de las Figuras 3 y 4, aunque la variación de  $K_p$  y  $K_d$  varían de forma diferente, ambos algoritmos encuentran un valor óptimo de constantes que producen un valor de IAE similar.

## 2.5 Optimización Por Colonia De Hormigas – ACO

El algoritmo de Optimización Por Colonia De Hormigas de (Rao, 2019) fue aplicado con los parámetros de entrada detallados a continuación:

- $Número_{actualizaciones} = 50$ , para evitar altos tiempos de ejecución.
- $Número_{hormigas} = 8$ , (Brownlee, 2011) sugiere un valor menor a diez para evitar altos tiempos de ejecución.
- Grado de importancia de las feromónas  $\alpha = 1$ , (Rao, 2019) sugiere que sea uno, es posible utilizar un valor más grande.
- Factor de decaimiento de feromóna  $\rho$ , (Rao, 2019) sugiere que este entre 0.5 y 0.8. Probando el algoritmo con un valor como 0.1, es posible visualizar el fenómeno de decaimiento de feromóna cuando las hormigas dejan de seguir los caminos en la Figura 5 en cada actualización.

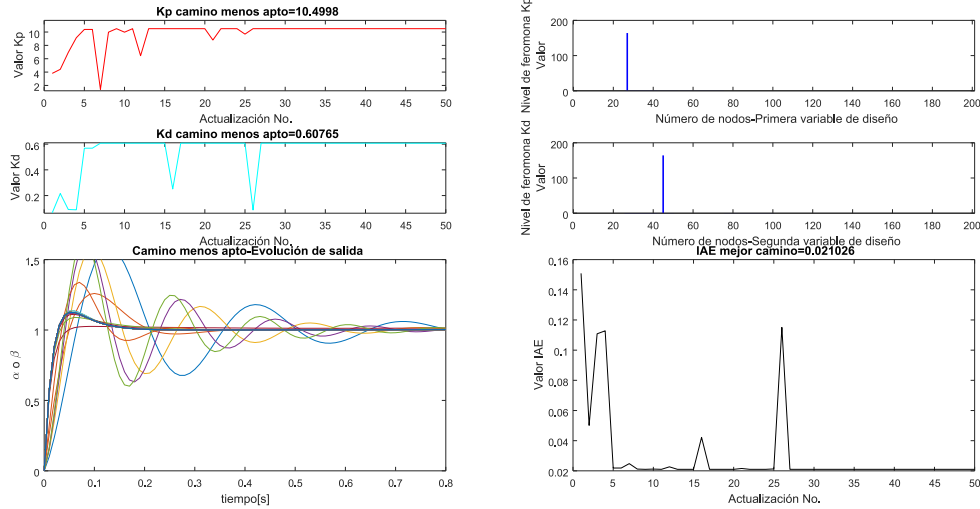


Figura 5: Proceso de optimización del Algoritmo de Colonia de Hormigas de un experimento

- $Número_{nodos} = 200$ . En contraste con los algoritmos GA y EP que utilizan operadores de cruce y recombinación, lo que implica que los miembros cambian su  $Kp$  y  $Kd$  en cada generación, el algoritmo ACO presenta una solución heurística inicial que puede ser representada por una matriz de dos filas ( $Kp$  y  $Kd$ ) por columnas de "Número de nodos", dichos valores no cambian en cada actualización, por lo que el algoritmo ACO busca la solución optimizada combinando las posibles rutas desde la primera fila hasta la última fila en todas las columnas posibles. Por el hecho mencionado, se definió el número de nodos realizando pruebas con el algoritmo, en donde valores más altos implica que hay más soluciones por explorar.

La Figura 5 detalla la actualización de  $Kp$ ,  $Kd$ , IAE y la salida del camino menos apto seguido por las hormigas. Además muestra el valor de feromona para cada nodo. Para el experimento de la Figura 5, todas las hormigas terminan siguiendo los nodos  $Kp_{nodo}=28$  y  $Kd_{nodo}=45$  en la última actualización y no existe rastro que alguna hormiga esté siguiendo cualquier otro camino.

## 2.6 Optimización Por Cúmulo De Partículas – PSO

El algoritmo de Optimización Por Cúmulo De Partículas de (Brownlee, 2011) fue aplicado con los parámetros de entrada detallados a continuación:

- $Número_{actualizaciones} = 30$ , para evitar altos tiempos de ejecución.
- $Número_{partículas} = 20$ , (Brownlee, 2011) sugiere que el número de partículas sea desde 20 hasta 40.

La Figura 6 indica la actualización de  $Kp$ ,  $Kd$ , IAE y la salida que corresponde a las posiciones menos y más apta. Además, se muestra como la partícula menos apta sigue a la partícula más apta en un espacio bidimensional.

## 2.7 Sistema Inmune Artificial – SIA

El algoritmo de selección clonal que pertenece a los algoritmos de los sistemas inmunes artificiales detallado en (Brownlee, 2011) y (Bennis and Bhattacharjya, 2020) fue aplicado con los parámetros de entrada detallados a continuación :

- $Número_{generaciones} = 50$ , para evitar altos tiempos de ejecución.
- $Población = 20$ , para evitar altos tiempos de ejecución.



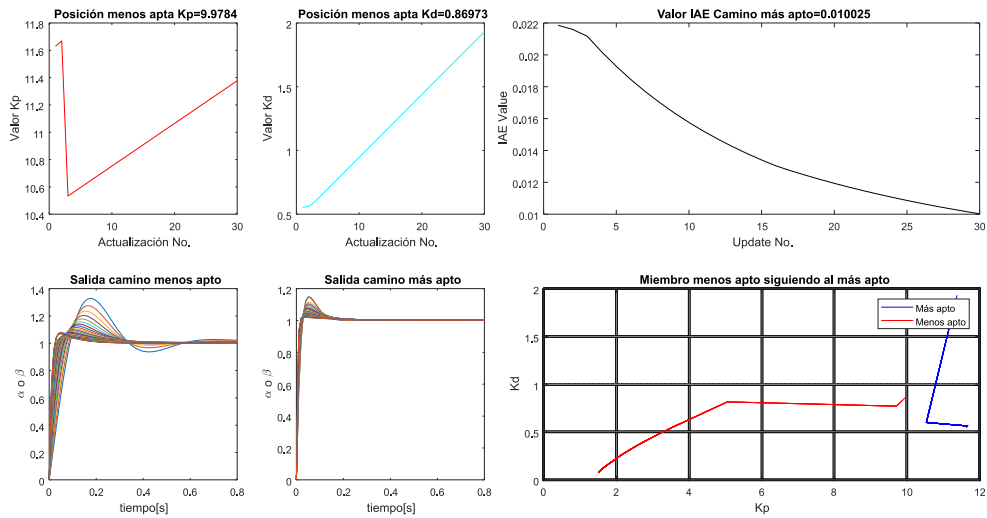


Figura 6: Proceso De Optimización Del Algoritmo De Optimización Por Cúmulo De Partículas de un experimento

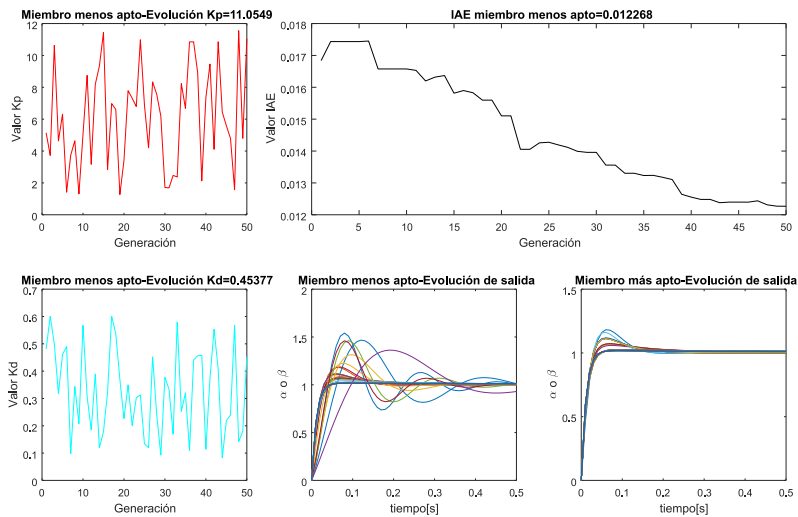


Figura 7: Proceso De Optimización Del Sistema Inmune Artificial

- $Tamaño_{selección} \leq 10$ , es el número de anticuerpos seleccionados de la población que serán proporcionalmente clonados. Probando el algoritmo con un número más grande, el mismo se centraría en buscar soluciones óptimas dentro de un grupo más reducido.
- $Anticuerpos_{aleatorios} = 1$ , Este algoritmo presenta la particularidad de que, en cada actualización o generación, se insertan uno o dos anticuerpos aleatorios en la población para evitar perder nuevos espacios de búsqueda que puedan contener nuevas soluciones óptimas.

La Figura 7 presenta la actualización de Kp, Kd, IAE, salida de la salida menos y más apta. La salida o respuesta que produce la célula menos apta puede presentar inestabilidad debido a que en cada actualización se inserta una célula aleatoria a la población de células.

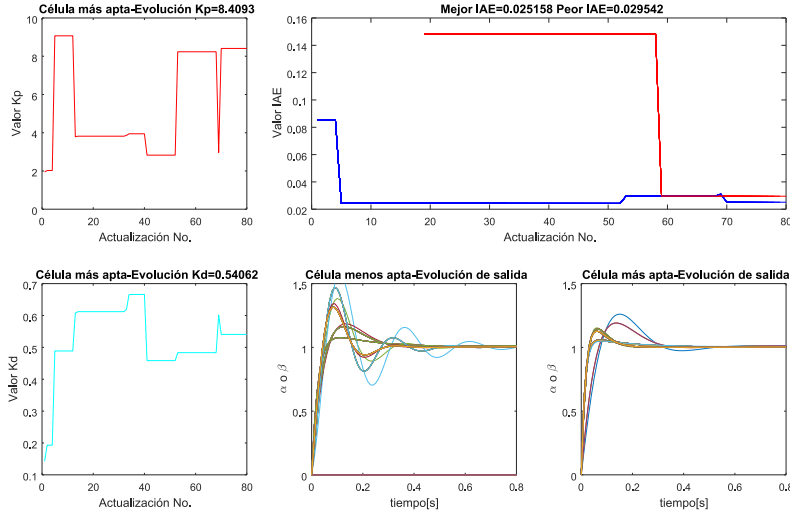


Figura 8: Proceso De Optimización Algoritmo de Forraje de Bacterias de un experimento

## 2.8 Algoritmo De Forraje De Bacterias – BFOA

El algoritmo de Forraje de bacterias propuesto por (Brownlee, 2011) fue implementado con los siguientes datos de entrada:

- $N_{\text{Número células}}=10$ , Este valor se recomienda que sea bajo debido a que el algoritmo requiere varios lazos for anidados. Utilizando valores mayores, el tiempo de ejecución se incrementaría de forma exponencial.
- $N_{ed} = 2$ , Número de pasos de eliminación y dispersión.
- $N_{re} = 1$ , Número de pasos de reproducción.
- $N_c = 2$ , Número de pasos de quimiotaxis.
- $N_s = 2$ , Número de pasos de nado para una célula.
- $T_{\text{tamaño}_{\text{paso}}} = 0,1$ , sugerido por (Brownlee, 2011).
- $d_{\text{atracción}} = 0,1$ , sugerido por (Brownlee, 2011).
- $w_{\text{atracción}} = 0,2$ , sugerido por (Brownlee, 2011).
- $h_{\text{repulsión}} = 10$  y  $w_{\text{repulsión}} = 10$ , sugerido por (Brownlee, 2011).
- $P_{ed} = 0,25$  sugerido por (Brownlee, 2011).

La Figura 8 presenta la actualización de Kp, Kd, IAE, la salida de la célula menos apta y la salida de la celda más apta. A diferencia de todos los demás algoritmos, el algoritmo BFOA se detiene en base a los valores definidos en  $N_{ed}$ ,  $N_{re}$ ,  $N_c$ , y  $N_s$ , no en base a un número de actualizaciones / generaciones.

## 2.9 Análisis de desempeño con la prueba ANOVA de Welch

Se realizaron cien pruebas para cada bio-algoritmo con el fin de obtener cien mejores IAE (Error Absoluto Integral) como conjunto de resultados. La prueba ANOVA de Welch que se muestra en (Liu, 2015) permite decidir si la media aritmética entre dos o más conjuntos de resultados son iguales o no, esta prueba es adecuada para grupos que siguen una distribución normal estándar y la varianza de al menos un conjunto de resultados es muy diferente de los otros.

Verificando el gráfico QQ y el histograma de la Figura 9, el conjunto de datos para cada algoritmo sigue una distribución normal estándar y la varianza del GA en la en la Tabla 2 es diferente respecto a




Figura 9: Diagrama QQ, histograma y diagrama de caja para 100 experimentos.

las varianzas de los algoritmos restantes. Los hechos mencionados ratifican que se puede aplicar la prueba ANOVA de Welch.

En (Liu, 2015), la prueba ANOVA de Welch define dos hipótesis y el nivel de significancia de la siguiente manera:

- Define las Hipótesis nulas,  $H_0$ : la media de cada conjunto de resultados es igual.
- Define las hipótesis alternativas,  $H_1$ : no todas las medias son iguales.
- Define el nivel de significancia,  $\alpha = 0,05$ .

Siguiendo el procedimiento propuesto en (Liu, 2015), el resultado del ANOVA de Welch se reporta de la siguiente manera: el valor p es cero, el cual es menor que el nivel de significancia,  $\alpha = 0,05$ , por lo que es posible concluir que la Hipótesis Nula es rechazada y se acepta la hipótesis alternativa. Esto significa que al menos una media aritmética no es igual, lo que es confirmado en el diagrama de caja de la Figura 10, en la cual el algoritmo PSO tiene una media aritmética del IAE inferior al de los otros algoritmos.

### 3 Resultados y Discusión

#### 3.1 Análisis de resultados para varios experimentos con la función de transferencia

Comparando los gráficos Q-Q de las Figuras 9 y 10, al aumentar el número de experimentos de cien a doscientos, todos los algoritmos siguen una distribución normal excepto el algoritmo ACO. Lo mencionado se puede confirmar revisando el histograma de la Figura 10 en donde el algoritmo ACO presenta un alto nivel de sesgo negativo.




Figura 10: Diagrama QQ, histograma y diagrama de caja para 200 experimentos.

Analizando el gráfico QQ y diagrama de caja de la Figura 11, al aumentar el número de experimentos de doscientos a trescientos, el algoritmo BFOA deja de seguir una distribución normal adicional al algoritmo ACO, debido a que los histogramas comienzan a tener un sesgo negativo y los diagramas de caja muestran una distribución más extendida, esta tendencia era esperada debido a la naturaleza heurística de los algoritmos, si es el número de experimentos aumenta la probabilidad de tener mas soluciones aleatorias también aumenta.

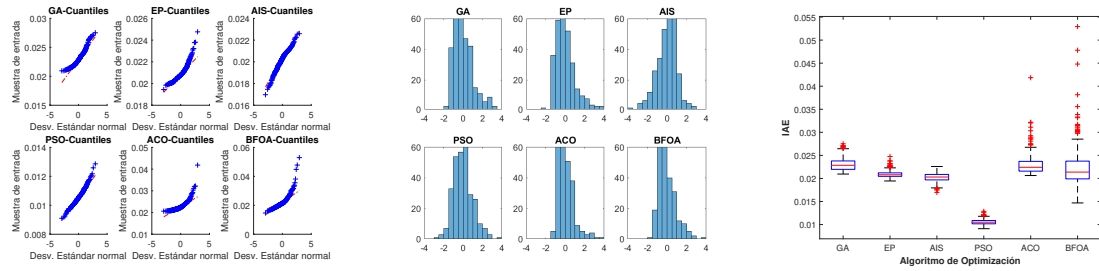


Figura 11: Diagrama QQ, histograma y diagrama de caja para 300 experimentos.

En la Figura 12 se detalla la salida del individuo menos apto de la primera y última actualización/generación de un experimento para cada uno de los algoritmos utilizados. Dada la naturaleza heurística de los algoritmos, existe un amplio rango de respuestas de primera generación al escalón unitario y es evidente que los algoritmos cumplen el objetivo de minimizar u optimizar el valor del IAE. Los algoritmos PSO y BFOA encontraron la combinación óptima de  $K_p$  y  $K_d$  para generar las respuestas al escalón unitario que tienen un valor inferior de sobreimpulso respecto a los demás algoritmos.

No obstante, todas las respuestas al escalón obtenidas de cada algoritmo de optimización muestran un sobreimpulso, tiempo de subida y tiempo de establecimiento aceptables para el sistema BALL AND PLATE.




Figura 12: Respuesta del individuo menos apto en la primera y última generación/actualización

Los algoritmos de optimización bioinspirados emplean procedimientos heurísticos y dependen en gran medida de los parámetros de entrada que son inherentes a cada algoritmo, por lo que no es exacto afirmar que un algoritmo es mejor que los demás. Sin embargo, para las entradas y rangos iniciales de búsqueda considerados para cada algoritmo, y con los resultados obtenidos en los diagramas de caja de las Figuras 9, 10 y 11, es posible ordenar los algoritmos, siendo primero el algoritmo que encontró el valor medio de IAE más bajo para el número de experimentos como se muestra en las Tablas 2,3 y 4.

La Tabla 5 muestra la media aritmética del tiempo requerido para la ejecución, el algoritmo BFOA tiene el menor tiempo de ejecución y el algoritmo SIA tiene el mayor tiempo de ejecución. Realizando un análisis global, todos los algoritmos presentan un balance óptimo encontrando el valor óptimo del IAE en un tiempo de ejecución adecuado. Para todos los experimentos, la Tabla 5 comprueba que existe una alta repetitibilidad respecto al tiempo de ejecución para encontrar óptimos globales.

### 3.2 Cambio de valor de consigna en el sistema BALL AND PLATE

Previo a realizar cualquier experimento es necesario realizar una calibración de la cámara colocando -8 y -2 en el Offset x y Offset y respectivamente.

Realizando un cambio de posición deseado de la bola sobre el plato desde -190mm hasta 190 mm y posteriormente volver a -190mm mientras se mide durante 25 segundos el ángulo alfa deseado y actual del

Tabla 2: Resultados de 100 experimentos

Posición/Grupo	$\mu_{IAE}$	$Min_{IAE}$	$Max_{IAE}$	Std. Dev( $10^{-3}$ )	Varianza( $10^{-3}$ )
1 PSO	0,01069	0,0095	0,01271	0,6187	0,000382
2 SIA	0,02029	0,01712	0,02228	0,9081	0,000824
3 EP	0,02096	0,01958	0,02319	7,1310	0,000508
4 BFOA	0,0222	0,01697	0,03445	3,3060	0,001093
5 ACO	0,02277	0,02081	0,02932	1,7508	0,003065
6 GA	0,02306	0,02069	0,02784	1,4378	20,675

Tabla 3: Resultados de 200 experimentos

Posición/Grupo	$\mu_{IAE}$	$Min_{IAE}$	$Max_{IAE}$	Std. Dev( $10^{-3}$ )	Varianza( $10^{-3}$ )
1/PSO	0,01063	0,00947	0,01344	0,6497	0,00422
2/SIA	0,02017	0,01744	0,02319	0,8891	0,00791
3/EP	0,02093	0,01984	0,02358	0,6915	0,00478
4/BFOA	0,02273	0,01606	0,05125	4,3281	0,18732
5/GA	0,02305	0,02070	0,02918	1,4127	0,01996
6/ACO	0,02321	0,02068	0,03747	2,7404	0,07510

Tabla 4: Resultados de 300 experimentos

Posición/Grupo	$\mu_{IAE}$	$Min_{IAE}$	$Max_{IAE}$	Std. Dev( $10^{-3}$ )	Varianza( $10^{-3}$ )
1/PSO	0,01056	0,00910	0,01286	0,5734	0,000329
2/SIA	0,02021	0,01697	0,02259	0,9148	0,000837
3/EP	0,02092	0,01945	0,02476	0,7235	0,000523
4/BFOA	0,02242	0,01469	0,05294	4,4573	0,019868
5/ACO	0,02298	0,02063	0,04185	2,1795	0,004750
6/GA	0,02304	0,02095	0,02752	1,3351	0,001783

Tabla 5: Media aritmética de tiempos de ejecución

No. de Experimentos	GA	EP	SIA	PSO	ACO	BFOA
100	2,66	3,89	4,79	2,60	0,67	0,54
200	2,91	3,94	4,81	2,62	0,67	0,53
300	2,65	3,89	4,79	2,60	0,67	0,52

plato utilizando las constantes obtenidas en los procesos de optimización de cada algoritmo detallados en las Figuras 3, 4, 5, 6, 7 y 8 resumidas en la Tabla 6, las optimizaciones producen el cambio de ángulo del plato detallado en la Figura 13, analizando las mismas se puede observar que el seguimiento de la señal de salida a la señal de referencia es satisfactorio en todos los experimentos excepto en el ciclo de subida del algoritmo PSO que tiene un pequeño desfase respecto al valor final, sin embargo todas las respuestas presentan un valor bajo de IAE con valores similares.

### 3.3 Seguimiento de trayectoria circular en el sistema BALL AND PLATE.

Utilizando las constantes de la Tabla 6 se alimenta al sistema una señal senoidal con una amplitud de 0.18 radianes y periodo de 6.7 segundos que varía el movimiento del plato en ambos ángulos alfa y beta, el experimento mencionado genera el seguimiento satisfactorio de trayectoria de la bola sobre el plato

Tabla 6: PD optimizado para pruebas en sistema real

Algoritmo	Kp	Kd[s]	Td[s]	Td[ $\mu$ s]
GA	11,7400	0,59581	0,05075	0,000846
EP	10,6168	0,65324	0,06152	0,001026
ACO	10,4998	0,60765	0,05787	0,000965
PSO	9,97840	0,86973	0,08716	0,001453
SIA	11,0549	0,45377	0,04105	0,000685
BFOA	8,40930	0,54062	0,06429	0,001072




Figura 13: Cambio de Ángulo, optimización por GA, EP, ACO, PSO, SIA y BFOA

detallado en la Figura 14, siendo la señal en azul el valor de consigna y la señal verde la posición actual de la bola sobre el plato. Además se muestra en la Figura 15 el seguimiento del plato a la señal senoidal en función del tiempo para los seis algoritmos de optimización, en la misma figura se puede observar que la señal de salida y de entrada tienen una frecuencia y amplitud similar adicional a un desfase mínimo característico de los sistemas dinámicos. Los IAE obtenidos en el experimento de seguimiento de trayectoria detallados en la Figura 15 son similares para todos los algoritmos.

### 3.4 Entrada escalón invertida en el sistema BALL AND PLATE.

Utilizando las constantes de la Tabla 6 se alimenta al sistema con una señal cuadrada durante 25 segundos con una amplitud 0.18 rad que se invierte cada 6.7 segundos, el experimento mencionado produce los datos en la Figura 16, en donde se puede observar que la señal medida presenta una respuesta dinámica adecuada, con buen tiempo de asentamiento y bajo o nulo sobre impulso.

En la Tabla 7 se resumen los valores de IAE para cada algoritmo de optimización meta heurístico para cada uno de los experimentos realizados en la planta para las tres señales de entrada: Cambio de consigna, señal senoidal y escalón invertido.

## 4 Conclusiones

En el presente estudio, se desarrollaron seis bio-algoritmos y se aplicaron a la función de transferencia para obtener una combinación óptima de constantes de un controlador PD con el objetivo de minimizar el valor del IAE y posteriormente probar las constantes obtenidas en el sistema Rolling Ball/Plate modelo 33-240 del fabricante National Instruments.

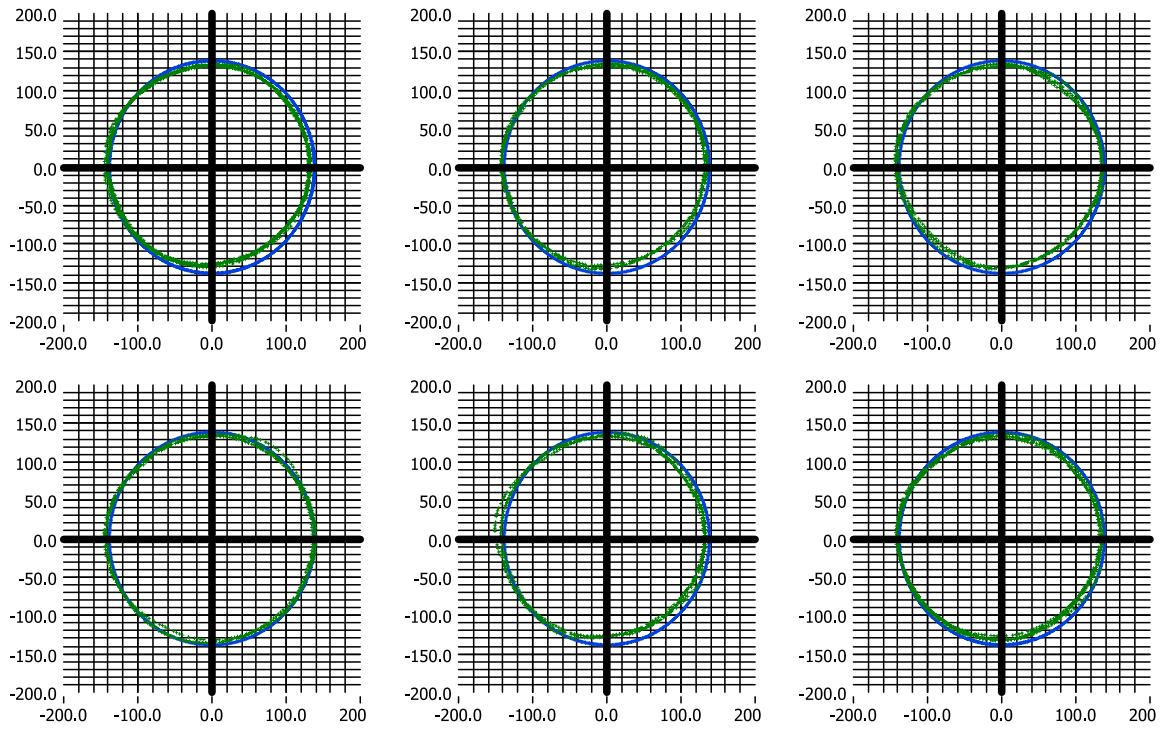


Figura 14: Seguimiento de trayectoria, optimización por GA, EP, ACO, PSO, SIA y BFOA

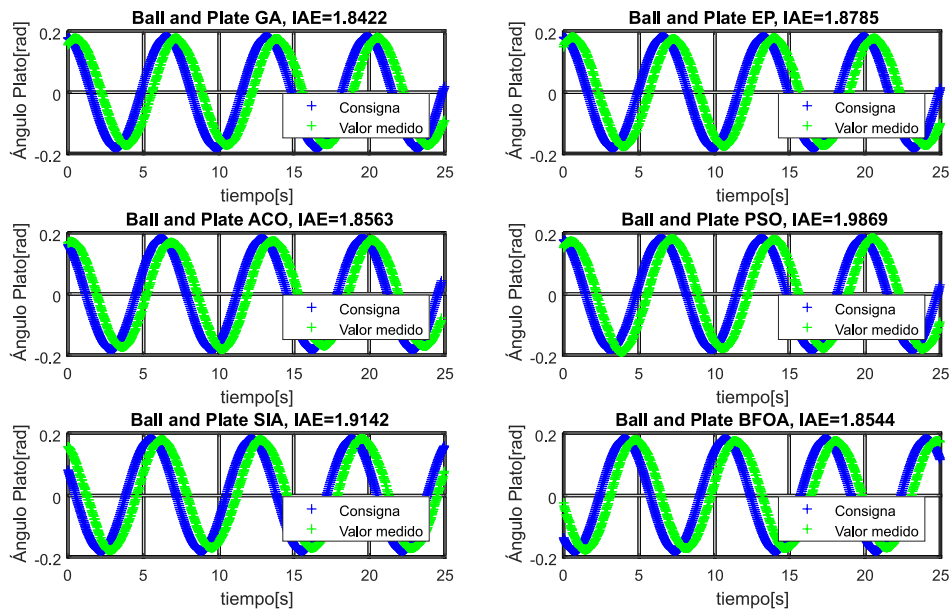


Figura 15: Entrada Senoidal y Ángulo del plato vs tiempo para cada Algoritmo

Las pruebas en simulación permiten concluir que el algoritmo PSO obtiene la media aritmética del valor IAE menor respecto a los demás algoritmos en cien, doscientos y trescientos experimentos con un tiempo de ejecución aceptable.

Los experimentos realizados demuestran que, si bien la implementación es muy diferente para cada

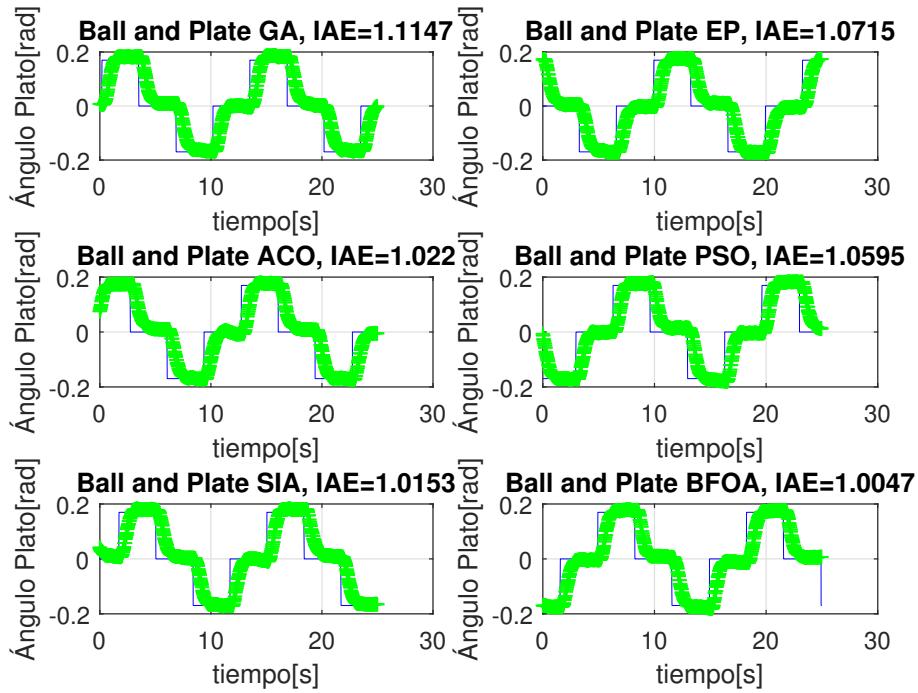


Figura 16: Entrada cuadrada y Ángulo del plato vs tiempo para cada Algoritmo

Tabla 7: IAE para diferentes señales de entrada

Algoritmo	IAE cambio consigna	IAE señal senoidal	IAE escalón invertido
GA	0,48127	1,8422	1,1147
EP	0,5425	1,8785	1,0715
ACO	0,54634	1,8563	1,0220
PSO	0,60193	1,9869	1,0595
SIA	0,52574	1,9142	1,0153
BFOA	0,47818	1,8544	1,0047

algoritmo, los resultados muestran que todos convergen a valores óptimos globales.

Analizando la parte teórica y práctica de la sintonización de controladores PID mediante algoritmos bio-inspirados se puede concluir que utilizar los algoritmos mencionados permite encontrar valores óptimos y funcionales de constantes PID en cuestión de segundos.

Las interfaces desarrolladas permitieron mostrar y emular el comportamiento de los fenómenos naturales en los que se basa cada algoritmo para resolver un problema de optimización del sistema de control para un Rolling Ball/Plate realimentado por visión artificial.

La prueba ANOVA de Welch aplicada a cien experimentos permite concluir que el algoritmo PSO generó un valor medio de IAE diferente al resto de los valores medios del IAE de los demás algoritmos, esto se verificó mediante diagramas Q-Q y de caja que se crearon en base a cien, doscientos y trescientos experimentos.

Mediante las pruebas realizadas en la planta Rolling Ball/Plate 33-240 con los controladores PD sintonizados por algoritmos bio inspirados se puede concluir que los mismos encontraron valores óptimos globales y su funcionamiento fue probado satisfactoriamente con varias señales de entrada como: cambio de consigna, entrada senoidal y cambio de entrada tipo escalón.

Analizando los valores del IAE correspondientes a la Tabla 7, se puede concluir que aunque los



valores del IAE son muy similares para cada algoritmo meta heurístico, el algoritmo de forraje de bacterias presentó el menor valor IAE con la entrada cambio de consigna y escalón invertido, finalmente el algoritmo genético presentó el menor valor IAE para la entrada senoidal.

Un estudio futuro se podrá realizar utilizando los mismos algoritmos para sintetizar controladores PID en línea o fuera de línea para cualquier planta representada por una función de transferencia.

## 5 Agradecimientos

Agradezco infinitamente a toda mi familia y seres queridos por darme todo el cariño, apoyo y motivación necesaria para seguir adelante en la vida ante cualquier adversidad.

Agradezco también a todos mis mentores y a GIECA que con su ejemplo, enseñanzas y apoyo han hecho posible desarrollar este trabajo de la mejor forma posible.

## Referencias

- F. Bennis and R. K. Bhattacharjya. *Nature-Inspired Methods for Metaheuristics Optimization: Algorithms and Applications in Science and Engineering*, volume 16. Springer, 2020.
- A. Bensenouci. Pid controllers design for a power plant using bacteria foraging algorithm. In *2011 Saudi International Electronics, Communications and Photonics Conference (SIEPCPC)*, pages 1–6. IEEE, 2011.
- M. Borah, L. Majhi, P. Roy, and B. Roy. Design of a fractional order pd controller tuned by firefly algorithm for stability control of the nonlinear ball and plate system. In *IEEE International Conference on Advanced Communication Control and Computing Technologies, Ramanathapuram, India, 2014*.
- J. Brownlee. *Clever algorithms: nature-inspired programming recipes*. Jason Brownlee, 2011.
- D. Colón, J. M. Balthazar, C. A. dos Reis, Á. M. Bueno, I. S. Diniz, and S. de SRF Rosa. Control design and robustness analysis of a ball and plate system by using polynomial chaos. In *AIP Conference Proceedings*, volume 1637, pages 226–234. American Institute of Physics, 2014.
- H. Kyongwon, T. Yantao, K. Yongsu, L. Jinsong, and Z. Yinghui. Tracking control of ball and plate system using a improved pso on-line training pid neural network. In *Mechatronics and Automation (ICMA), 2012 International Conference on*, pages 2297–2302, 2012.
- H. Liu. Comparing welch’s anova, a kruskal-wallis test and traditional anova in case of heterogeneity of variance. 2015.
- M. Moarref, M. Saadat, and G. Vossoughi. Mechatronic design and position control of a novel ball and plate system. In *2008 16th Mediterranean Conference on Control and Automation*, pages 1071–1076. IEEE, 2008.
- S. S. Rao. *Engineering optimization: theory and practice*. John Wiley & Sons, 2019.
- X. Wang, M. Wu, L. Ouyang, and Q. Tang. The application of ga-pid control algorithm to dc-dc converter. In *Proceedings of the 29th Chinese Control Conference*, pages 3492–3496. IEEE, 2010.
- L. A. Yusuf and N. Magaji. Ga-pid controller for position control of inverted pendulum. In *2014 IEEE 6th International Conference on Adaptive Science & Technology (ICAST)*, pages 1–5. IEEE, 2014.
- S. Zhang, C. Zhu, J. K. Sin, and P. K. Mok. A novel ultrathin elevated channel low-temperature poly-si tft. *IEEE Electron Device Letters*, 20(11):569–571, 1999.